

平成 29 年度（2017 年度）学位論文（修士）

飛行と気象の状況による飛行時間の不確かさのモデル化

平成 30 年（2018 年）2 月 22 日

首都大学東京大学院

システムデザイン研究科 システムデザイン専攻

航空宇宙システム工学域 博士前期課程

16891538 元谷章博

指導教員 武市昇

目次

1.	はじめに.....	2
2.	使用するデータとその処理.....	3
2.1	使用するデータ.....	3
2.2	飛行時間誤差の推定.....	3
2.3	類似する飛行状況ごとにクラスタリング.....	6
3.	飛行時間の誤差伝搬モデル.....	8
3.1	飛行時間の誤差伝搬モデルの導出.....	8
3.2	予測性能の比較評価.....	9
4.	飛行状況ごとに予測可能なモデル.....	12
4.1	ニューラルネットワークによる学習と評価方法.....	12
4.2	学習に使用する教師データ.....	14
4.3	予測性能の評価.....	15
5.	予測モデルの軌道データへの適用.....	17
5.1	評価指標.....	17
5.2	全軌道に対する平均的な予測性能.....	18
5.3	飛行状況に応じた予測モデルの有益性.....	19
6.	まとめ.....	21
7.	謝辞.....	22
8.	参考文献.....	23

1. はじめに

世界的な経済成長や国際化により航空交通需要の増加が予測されている^[1]。この需要増加に対応すべく航空交通管理システムの抜本的な変革が計画されており、その一つに現行の空域ベース運用から軌道ベース運用への移行が挙げられる。この軌道ベース運用において各航空機は予め戦略的に設計された離陸から着陸までの軌道に沿って飛行し一元的に管理される^[2]。この交通流全体の一元的な管理の実現にむけて、各航空機の正確な時間管理が重要となる。そこで、四次元航法が注目されている。四次元航法とは、航空機の飛行経路を通過地点とその通過時刻により指定し、精密な時間管理を目指す運航管理の方法である^[3]。予め戦略的に決定された四次元の飛行経路を計画通りに飛行することで、各航空機の厳密な時間管理と交通流全体の一元管理が可能となる。

しかし、与えられた四次元経路を目指して飛行しても、飛行中の航空機は気象などの確率的な影響を受けるため通過時刻には誤差が生じる。この飛行時間の誤差の程度、すなわち飛行時間の不確かさを事前に予測し管理に導入することで、より効率的な運用が可能になるものと考えられている。例えば、飛行時間の不確かさを正確に予測し管理に導入することができれば、航空機の時間間隔を安全性を確保しつつ縮小させることができ、空域容量の拡大が可能になる。この他にも、最終目的地への定刻性を向上させるための速度修正ポイントの最適配置や、管制官の負荷と運航コストを同時に低減できるなど、飛行時間の不確かさが予測できた場合の効率的な運航管理手法が複数報告されている。

このような高度な運航を目指して、飛行時間の不確かさの予測やモデル化に関する研究が行われてきた。その中で、飛行時間誤差の標準偏差が飛行距離あるいは時間に比例することが理論的に示され^[4,5]、さらに複数の研究において、特定の期間（数日～数年）の特定の経路の航空機の飛行時間を解析し、飛行時間誤差の標準偏差が飛行距離あるいは時間に比例することが実証されている^[6-8]。このように従来の研究では、飛行時間の不確かさと飛行距離や時間との比例関係のみを示す単純なモデルが得られているのみである。しかし本来、飛行時間の誤差は気象状況や飛行動態に応じて変動すると考えられる。このため、従来のモデルによる、「いかなる気象や飛行の状況においても同距離（もしくは同時間）飛行した時に生じうる飛行時間の誤差の程度は等しい」という予測では、飛行時間の不確かさが生じる現象を単純化しすぎていることで精度が損なわれていると想定できる。

そこで本研究では、飛行時間の不確かさの予測モデルの高精度化を目指し、気象や飛行の状況を予測に反映したモデルを構築することを目指す。次章では、飛行時間の不確かさを気象や飛行の状況ごとに解析するためのデータを用意すべく、実運航データに施すデータの前処理について述べる。3章では、単純な力学モデルに基づいて飛行時間の不確かさをモデル化する。4章では、気象や飛行の状況ごとに変動する要因を予測に反映させるべく、飛行状況を表すパラメータと飛行時間の不確かさの関係をニューラルネットワークにより同定した近似モデルを構築する。5章では、実軌道データにモデルを適応した時の予測性能を評価する。最後に6章で、議論をまとめる。

2. 使用するデータとその処理

2.1 使用するデータ

本研究では、SSR Mode S システムにより取得した運航データを使用する。SSR Mode S システムが提供するデータ内容には、緯度・経度の位置情報に加え、指示大気速度、真大気速度、マッハ数、対地速度、気圧高度などの航空機からダウンリンクされた動態情報が含まれる^[9]。本研究では2015年8,9月に観測された運航データを使用する。また、数値気象予報値として気象庁が提供する全球モデル数値予報値 GSM^[10]を使用する。GSM の予報値は6時間毎に更新され、最も予測精度がよいと考えられる各予報時刻における初期予報値を緯度・経度・高度・時刻に対して線形補間し、任意の時刻・位置の気象予報値を得る。本研究では、風速と気温を使用する。

2.2 飛行時間誤差の推定

本研究では、飛行時間の不確かさを定量化した評価指標として飛行時間誤差の標準偏差を用いる。飛行時間の誤差は、目標飛行時間と実際の飛行時間の差で求めることができるが、前節で述べた SSR Mode S システムによる運航データからは各航空機の目標飛行時間を直接得ることができない。そこで、数値気象予報値 GSM を用いて各航空機の目標飛行時間を推定し、飛行時間誤差の推定に使用する。

目標飛行時間のように、各航空機が目指した飛行形態に関する情報を飛行意図という。この飛行意図を精度よく推定するために、明確な飛行意図を基づいて飛行しているとみなせる区間を抽出し、解析の対象とにする。巡航区間における航空機は、管制官の指示により指示大気速度を決定し、定められた航路に沿うように真航路角、気圧高度を保って飛行することが多い。そこで各軌道のうち、指示大気速度が $\pm 5[\text{kt}]$ 以内の変動で、かつ真航路角が $\pm 1.5[\text{deg}]$ 以内の変動で100km以上を巡航している区間、すなわち等速・直線・巡航飛行をしている飛行区間を明確な飛行意図をもつ区間として抽出した。ただし、各飛行軌道の気圧高度の最頻値から $\pm 100[\text{ft}]$ の区間を巡航区間とみなす。抽出されたデータ数は15643となった。抽出したデータの軌道を図1に示す。




図 1：抽出データの軌道（データ数：15643）

次に、抽出後の各飛行の目標飛行時間 T を推定する。式 (1) から、ある飛行距離 D を飛行するときの目標飛行時間 T の推定は、目標対地速度 V_{GS} の推定と等しい。実際の運航管理において、管制官からパイロットへの速度情報の管制指示は指示大気速度が用いられる。ある区間を目標飛行時間で飛行するための速度指示は、目標対地速度から数値気象予報値を用いて換算された指示大気速度が用いられる。そこで、本研究の目標飛行時間の推定には、抽出区間の指示大気速度の中央値をパイロットと管制官が意図した指示大気速度 V_{IAS} とみなし、この値から数値気象予報値を用いて逆算した対地速度を抽出区間における目標対地速度として用いる。まず式 (2) により、意図した指示大気速度 V_{IAS} を機首方向の真対気速度 V_{TAS}' に変換する。ただし、 p は気圧高度より標準大気モデルから求めた気圧、 ρ は気温から求めた大気密度である。これを式 (3) により真航路方向に変換した値を目標真対気速度 V_{TAS} とみなす。ただし、 θ_w は航空機の機首方向と真航路方向の差である。この目標真対気速度 V_{TAS} と真航路方向の風速 W_H の予報値の和から目標対地速度 $V_{GS} (= V_{TAS} + W_H)$ を求め、ある距離 D を飛行したときの目標飛行時間 T を推定する。式 (2), (3) の速度と方位角の関係を図 2 に図示する。また同区間の実際の飛行時間を実運航データに記録された対地速度から算出し、目標飛行時間 T との差をとることで飛行時間誤差を求め、この分布を図 3 に示す。飛行時間誤差の分布が 0 を中央に持つ正規分布に近い形状となっていることから、一連の計算により飛行時間誤差が適切に推定できていることが確認できる。

$$T = \frac{D}{V_{GS}} \quad (1)$$

$$V'_{TAS} = \left[\frac{2p}{\mu\rho} \left\{ \left(1 + \frac{p_0}{p} \left[\left(1 + \frac{\mu\rho_0}{2p_0} V_{IAS}^2 \right)^{\frac{1}{\mu}} - 1 \right] \right)^\mu - 1 \right\} \right]^{\frac{1}{2}} \quad (2)$$

$$V_{TAS} = V'_{TAS} \cos \theta_W \quad (3)$$




図 2：航空機 の速度と方位角




図 3：推定した飛行時間誤差のヒストグラム（データ数：15643）

2.3. 類似する飛行状況ごとにクラスタリング

前述したように飛行時間の不確かさを定量的指標として、飛行時間誤差の標準偏差を用いる。標準偏差を算出するためには集合的に観測されたデータが必要であり、本研究の目的に即して飛行状況ごとに算出するためには、類似する飛行状況ごとにデータを分類する必要がある。このように、データの全集合から類似する特徴パラメータをもつデータ集合に分類する手法をクラスタリングといい、分類後のデータ集合をクラスタという。ここではクラスタリングの基準となる特徴パラメータに、気象や飛行の状況を表すパラメータを用いることにより、分類後のクラスタによって類似する気象状況で類似する飛行意図を持ったデータ集合を構成する。ここでは特徴パラメータに、気象状況を表す真航路方向の風速、横風の絶対値、気温と飛行意図を表す目標対地速度を用いる。

各クラスタ内の特徴パラメータの平均値や飛行時間誤差の標準偏差などの各種統計量を精度良く推定するため、各クラスタ内の特徴パラメータが中央に代表的なピークを持ち、極端な外れ値を含まない分布を形成することが望ましい。そこで混合正規分布モデルによるソフトクラスタリングを採用する。この手法では、まずデータを特徴パラメータ空間における複数の多次元正規分布の重ね合わせた混合正規分布としてモデル化する。このとき混合正規分布の確率密度関数の推定に EM (反復期待値最大化) アルゴリズム^[11]を用いた。ここで、あるデータ X が観測された時の正規分布 G_i の生起確率 $P(G_i|X)$ は、データ X の正規分布 G_i への所属度とみなすことができる。この所属度を用いて各データを所属する正規分布に確率的に割り当てることでクラスタリングする^[12]。このように正規分布を元にデータを割り当てる分類手法により、各クラスタの特徴パラメータ分布は概ね正規分布に従い、中央に代表値をもち極端な外れ値を持たない分布の形成を図る。

$$P(G_i|X) = \frac{P(X|G_i)P(G_i)}{\sum_{j=1}^M P(X|G_j)P(G_j)} \quad (4)$$

クラスタリングには抽出データ数の 2/3 (10429 個) の軌道データを用い、残りは 5 章で行う軌道データを用いた評価に用いる。また、対象データの分布を混合正規分布とみなしてモデル化するにあたり、構成する正規分布の数、すなわちクラスタの分割数を設定しなければならない。ここで、次章以降の解析で使用するクラスタ内の飛行時間誤差の標準偏差の推定精度を考慮して、50 以上のデータを持つクラスタのみ解析に有効なクラスタとして使用する。この解析に有効なクラスタを最も多く生成できる分割数を 200 個と特定し、結果として 164 個の解析に有効なクラスタを得た。この例として、あるクラスタ内の飛行時間誤差と特徴パラメータ (目標対地速度 V_{GS} 、真航路方向の風速 W_H 、横風の絶対値 $|W_C|$ 、気温 $Temp$) の分布を図 4 に示す。それぞれ中央に代表値をもち、外れ値を持たない所望の分布を形成できている。

以上の一連のデータ処理により、飛行状況を表すパラメータと飛行時間の標準偏差を対応付けたデータを用意した。これを次章以降の解析やモデル化およびモデルの評価に使用する。








図 4：クラスタ内の各パラメータのヒストグラム例（データ数：374）

3. 飛行時間の誤差伝搬モデル

本章では、航空機を質点としてみなした単純な力学モデルに基づく飛行時間の誤差伝搬モデルについて述べる。

3.1. 飛行時間の誤差伝搬モデルの導出

航空機を質点としてみなした単純な力学モデルにおいて、飛行時間 T と真対気速度 V_{TAS} および風速 W_H 、飛行距離 D の関係は式 (5) のようになる。ただし、真対気速度 V_{TAS} と風速 W_H はどちらも真航路方向成分を考える。飛行距離 D を一定とすると、飛行時間 T の誤差 ΔT の誤差要因になり得るのは、真対気速度 V_{TAS} および風速 W_H の誤差 ΔV_{TAS} 、 ΔW_H のみであり、この関係は式 (6) のように表せる。式 (5)、(6) を整理すると、飛行時間誤差 ΔT は、 ΔV_{TAS} と ΔW_H の関数として式 (7) のように表せ、さらに ΔV_{TAS} と ΔW_H を微小項とみなして線形化すると式 (8) を得る。また、式 (8) と分散の定義式から飛行時間誤差 ΔT の標準偏差 $\sigma_{\Delta T}$ は、式 (9) のように表せる。式 (9) は、誤差要因のばらつきが飛行時間誤差のばらつきに影響する関係を表しており、誤差伝搬モデルと呼ばれる。この誤差伝搬モデルは、一定距離を飛行するときの飛行時間誤差の標準偏差は対地速度の二乗に反比例し、その係数は真対気速度の誤差分散と風速の誤差分散によって決まることを示している。

$$T = \frac{D}{V_{TAS} + W_H} \quad (5)$$

$$T + \Delta T = \frac{D}{V_{TAS} + \Delta V_{TAS} + W_H + \Delta W_H} \quad (6)$$

$$\Delta T(\Delta V_{TAS}, \Delta W_H) = \frac{-(\Delta V_{TAS} + \Delta W_H)D}{(V_{TAS} + W_H)(V_{TAS} + \Delta V_{TAS} + W_H + \Delta W_H)} \quad (7)$$

$$\Delta T(\Delta V_{TAS}, \Delta W_H) \cong -\frac{D}{(V_{TAS} + W_H)^2} \Delta V_{TAS} - \frac{D}{(V_{TAS} + W_H)^2} \Delta W_H \quad (8)$$

$$\sigma_{\Delta T, Model} = \sqrt{E[(\Delta T)^2]} = \frac{\sqrt{\sigma_{\Delta V_{TAS}}^2 + \sigma_{\Delta W_H}^2}}{V_{GS}^2} D \quad (9)$$


3.2 予測性能の比較評価

この誤差伝搬モデルの予測性能を、比例係数 $\sqrt{\sigma_{\Delta V_{TAS}}^2 + \sigma_{\Delta W_H}^2}$ を(1)飛行状況によらず一律の値を用いた場合と(2)飛行状況ごとに適切な値を用いた場合を比較評価することで、飛行時間の不確かさ予測のモデルに飛行状況ごとの変動を反映することの有効性を確認する。(1)の場合は、飛行状況ごとに区別することなく、抽出した全飛行データより誤差要因の誤差の分散($\sigma_{\Delta V_{TAS}}^2$ と $\sigma_{\Delta W_H}^2$)を算出し、 $\sqrt{\sigma_{\Delta V_{TAS}}^2 + \sigma_{\Delta W_H}^2}$ の期待値を得た。それぞれの値は、 $\sigma_{\Delta V_{TAS}}^2 = 0.63[(\text{m/s})^2]$ 、 $\sigma_{\Delta W_H}^2 = 2.83[(\text{m/s})^2]$ となった。この飛行状況によらず一律の比例係数を用いた予測は、従来の研究の扱い方に相当する。


一方、(2)の場合は、2.3.節で得た飛行状況ごとのデータ集合を模擬したクラスタごとに $\sqrt{\sigma_{\Delta V_{TAS}}^2 + \sigma_{\Delta W_H}^2}$ を算出し、予測に用いた。これは、誤差要因の誤差分散の飛行状況ごとの変動を正確に予測できた場合の理想的な予測に相当する。

この比較評価結果を、(1)の場合は図 5-(a),(b)に、(2)の場合を図 6-(a),(b)にそれぞれ示す。図 5,6 の(a)は、誤差伝搬モデルによる予測値 $\sigma_{\Delta t, Model}$ とクラスタごとに算出した飛行時間誤差の標準偏差 $\sigma_{\Delta t, Est}$ の散布図を示す。青実線は回帰直線、黒点線は予測値と観測値が一致するときの直線である。このとき、予測性能を表す予測値と目標値の相関係数 R と $rmse$ は、(1)の場合 $R = 0.81(p < 10^{-10})$ 、 $RMSE = 0.069[\text{sec}/10\text{km}]$ 、(2) $R = 0.99(p < 10^{-10})$ 、 $RMSE = 0.018[\text{sec}/10\text{km}]$ の場合となった。また図 5,6 の(b)は、対地速度と飛行時間誤差の標準偏差の関係を示し、赤の線および点は誤差伝搬モデルの予測値を、黒の点はクラスタごとに算出した推定値を表す。図 5-(a)からは、誤差伝搬モデルの式からわかる飛行時間誤差の標準偏差が対地速度の二乗に反比例する傾向が確認できる。また、予測値と推定値をつなぐ青線の長さは予測の誤差の大きさに相当しており、予測精度が向上していることを可視的に確認できる。

以上の比較評価により、(1) 飛行状況によらず一律の比例係数を用いた場合よりも(2) 飛行状況ごとに適切な比例係数を用いた場合の方が高い予測性能を示すことから、飛行状況ごとに変動する要因をモデルに考慮することが飛行時間の不確かさ予測の高精度化に向けて効果的であることが確認できた。ただし(2)の結果は、飛行状況ごとの誤差要因の影響の変動を事前に正確に把握できた場合の予測性能を表しており、実際にはこれらの $\sigma_{\Delta V_{TAS}}^2$ や $\sigma_{\Delta W_H}^2$ を(1)の場合のように過去の観測データから算出した一律の実績値を用いるほかない。このため、誤差伝搬モデルの実際的な予測性能は(1)の結果であり、(2)は予測性能の理想値に相当する。そこで、次章では実運用において利用できる気象や飛行の状況ごとの詳細な予測ができるモデルを構築するために、事前に参照可能な気象予報値や飛行意図を表すパラメータから予測するモデルの構築を試みる。




(a) モデルの予測値—クラスタごとの算出値




(b) 対地速度—飛行時間の標準偏差

図 5: 誤差伝搬モデルの予測性能 (一律の比例係数を用いた場合)



(a) モデルの予測値—クラスタごとの算出値



(b) 対地速度—飛行時間の標準偏差

図 6：誤差伝搬モデルの予測性能（飛行状況ごとに適切な比例係数を用いた場合）

4. 飛行状況ごとに予測可能なモデル

前章では力学モデルから導いた誤差伝搬のモデルによる予測精度を比較評価することで、高精度な予測のために飛行状況ごとの誤差要因の変動をモデルに考慮することが有効であることを示した。そこで本章では、事前に参照可能な気象予報値や飛行意図を表すパラメータから飛行時間誤差の標準偏差を予測するモデルの構築に向け、これらの入出力特性をデータから機械学習的にモデル化することを試みる。3.1.節の誤差伝搬のモデルの導出では、簡単のために誤差項を微小とみなした一次線形化や誤差要因間が独立であるという仮定を置いたが、これによりモデルの粒度が不適切に損なわれる可能性もあるため、非線形性やパラメータ間の相互関係も反映できる学習モデルが望ましい。そこで、非線形性や複雑な相関構造を含め任意の入出力特性を近似関数化できるニューラルネットワークモデルを用いる。

4.1 ニューラルネットワークによる学習と評価方法

ニューラルネットワークによる教師データの学習について概説する。教師データとは、入力変数 x とそれに対応する出力変数 y の観測データ集合であり、この入出力関係をニューラルネットワークに学習させる。図7は、入力層・中間層・出力層の3層からなる3層ニューラルネットワークの例であり。以降、これを単にニューラルネットワークと呼ぶ。各層を構成する○はニューロンと呼ばれ、その働きを図8に示す。ニューロンへの入力 x_1, x_2 であるとき、これらに重み係数 w_1, w_2 を付けた総和とバイアス係数 θ の和である X を、ニューロン内部の活性化関数 f に入力したときの出力 $y = f(X)$ を得る(式(11))。ただし、活性化関数 f は式(12)のシグモイド関数という非線形関数を用いる。

$$y = f(X) = f(w_1x_1 + w_2x_2 + \theta) \quad (11)$$

$$f(X) = \frac{1}{1 + \exp(-X)} \quad (12)$$

このようなニューロンにより構成されたニューラルネットワークでは、入力変数 x_1, x_2, \dots, x_n と出力変数 y の任意の入出力関係を関数近似できることが知られている^[13]。

ニューラルネットワークは、 s 番目の教師データの出力変数 y_s とニューラルネットワークの出力 \hat{y}_s によって定義する式(13)のような誤差関数 E_s を最小にするように、重み係数 w を調節することで s 番目の教師データの入出力関係を学習することができる。誤差関数 E_s を減少させるような重み係数 w の更新量 Δw を式(14)のようにすればよい。ここで、図6のニューラルネットワークの出力 \hat{y}_s は式(11)から、式(15)のように表せ、非線形な活性化関数 f による合成関数の和として解釈できる。ただし、 IN_i^k は第 k 層の i 番目のニューロンへの入力の総和、 OUT_i^k は第 k 層の i 番目のニューロンの出力とする。式(14)と式(15)から、例えば入力層の j 番目のニューロンから中間層の i 番目のニューロンへの入力の重み係数 w_{ij}^1 の更新量 Δw_{ij}^1 は、式(16)のように表せる。式(16)のように、ニューラルネット

ワークの出力誤差を出力層側から入力層側に伝搬させるように更新量 Δw_{ij}^k を得ることから、この学習方法は誤差逆伝搬法と呼ばれている。この学習によって教師データの入出力関係をニューラルネットワークに学習させることができる。

$$E_s \propto (y_s - \hat{y}_s)^2 \quad (13)$$

$$\Delta w \propto -\frac{\partial E_s}{\partial w} \quad (14)$$

$$\hat{y}_s = IN_1^3 = \sum_{i=1}^m OUT_i^2 = \sum_{i=1}^m f(IN_i^2) \quad (15)$$

$$\Delta w_{ij}^1 \propto -\frac{\partial E_s}{\partial w_{ij}^1} = -\frac{\partial E_s}{\partial \hat{y}_s} \frac{\partial \hat{y}_s}{\partial IN_1^3} \frac{\partial IN_1^3}{\partial OUT_i^2} \frac{\partial OUT_i^2}{\partial IN_i^2} \frac{\partial IN_i^2}{\partial w_{ij}^1} \quad (16)$$

この重み係数の更新を、誤差関数 E_s が十分に小さくなるか、指定した最大更新回数まで繰り返す。ここでは、最大更新回数は1000回とした。また、ニューラルネットワークのように多くの調整係数を持つモデルによる学習でしばしば問題となる過学習の対策として、正則化項を追加した誤差関数により学習を行う。この手法は荷重減衰と呼ばれる^[14]。




図7：3層ニューラルネットワークの構成例




図8：ニューロンの働き

4.2. 学習に使用する教師データ

教師データのうち、入力変数に各クラスターの対地速度、真航路方向の風速、横風の風速、気温の平均値を、出力変数に 10km 当たりの飛行時間誤差の標準偏差を用いる。図 9 に、この教師データの各入力変数と出力変数の散布図と回帰係数 R およびその p 値を示す。気象や飛行の状況を表す各パラメータと飛行時間誤差の標準偏差には有意な相関がある。この教師データをニューラルネットワークに学習させることで、気象状況や飛行状況を表すパラメータと飛行時間誤差の標準偏差との関係を記述したモデル化を試みる。

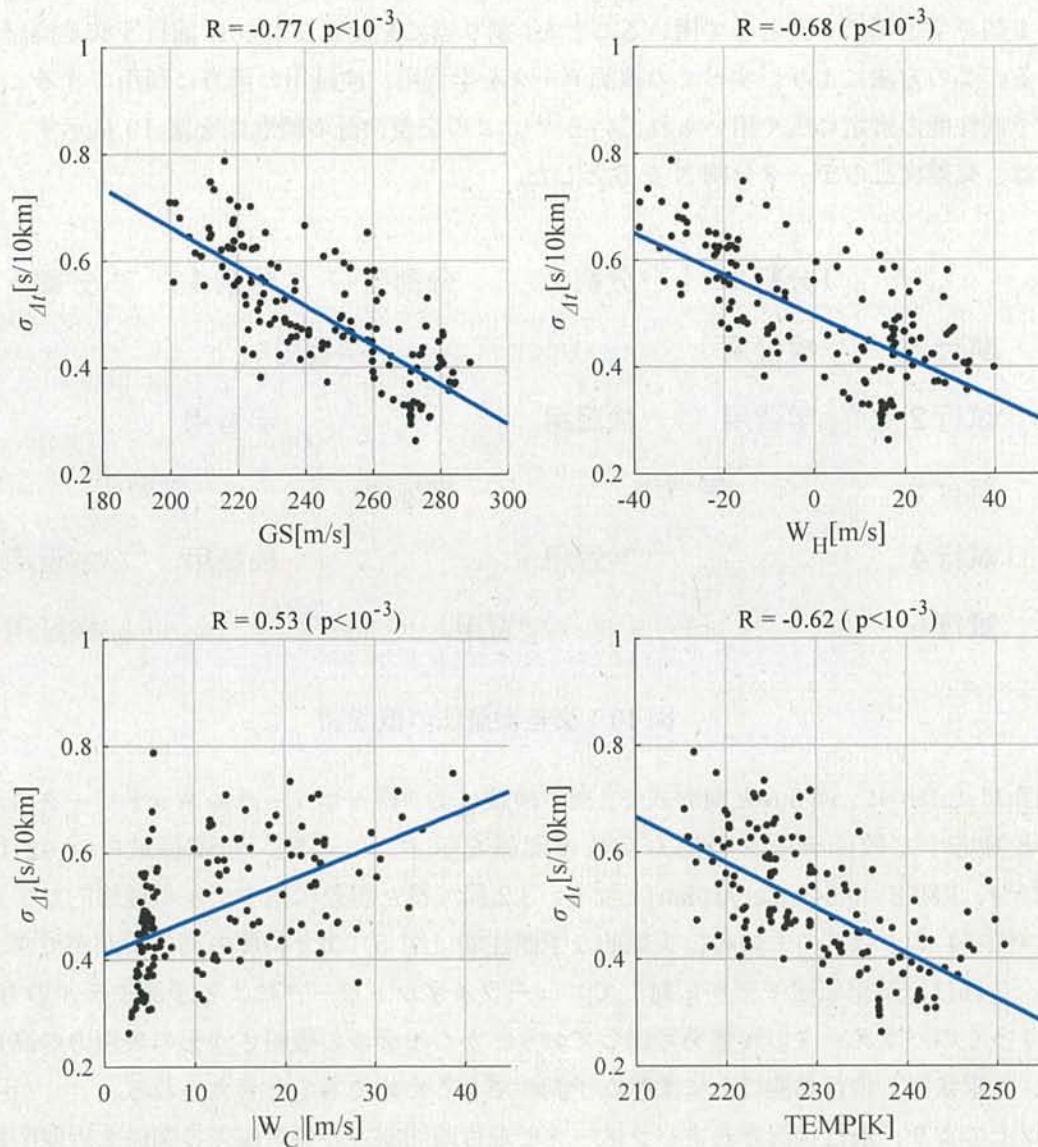


図 9：教師データの入出力特性

4.3 予測性能の評価


前述のとおり、ニューラルネットワークは教師データの出力変数との誤差が小さくなるよう重み係数を調整することで入出力特性を学習する。このため学習に使用したデータを予測性能の評価にも使用することモデルの汎用性を適切に評価できないため、学習に使用していない検証用データを予測性能の評価に用いなければならない。そこで、限られた教師データをどのように分割するかが問題となる。モデルの学習用データをより多く確保することで汎化性の高いモデルが得られるが、予測性能の検証用データの数が少ないと十分な予測性能評価ができない。そこで、N 個の教師データのうち 1 つを検証用データ、他の N-1 個を学習用データとして用いることを、割り当てを変えながら N 回行う交差検証を用いる。この方法により、すべての教師データを学習用、検証用の両方に利用できることから予測性能の推定に広く用いられている^[14]。この交差検証の概念図を図 10 に示す。ここでは、交差検証のデータ分割 N を 5 とした。

	分割 1	分割 2	分割 3	分割 4	分割 5
試行 1	検証用	学習用			
試行 2	学習用	検証用	学習用		
試行 3	学習用		検証用	学習用	
試行 4	学習用			検証用	学習用
試行 5	学習用				検証用


図 10：交差検証法の概説図

図 11-(a)(b)に、図 5,6 と同形式で、交差検証により得たニューラルネットワークの予測値と対応する教師データの出力変数の関係を示す。この時、相関係数 $R=0.92$ ($p < 10^{-10}$)、 $RMSE=0.046$ [sec/10km]となり、3.2.節で得た誤差伝搬モデルの理想的な予測精度（図 6）よりは劣るものの、実際のな予測性能（図 5）より精度の高い予測ができていいる。これは、誤差伝搬モデルに対してニューラルネットワークによる予測モデルの方が、より多くのパラメータの影響を考慮しており、かつモデルの複雑さゆえの表現力の高さから、気象状況・飛行動態ごとに柔軟な予測ができるためであると考えられる。

以上により、飛行状況を表すパラメータと飛行時間誤差の標準偏差の関係を近似関数として表すことができ、気象や飛行の状況に応じた詳細な予測が可能なモデルを構築できた。ここまでの飛行時間の不確かさ分析およびモデル化には、2.3.節の類似する飛行状況にグループ化したクラスターデータを用いている。次章では、予測モデルの実際的な適用を想定し、グループ化したデータ集合ではなく実軌道データにおける予測性能を評価する。



(a) モデルの予測値—クラスタごとの算出値



(b) 対地速度—飛行時間の標準偏差

図 11：ニューラルネットワークモデルの予測性能

5. 予測モデルの軌道データへの適用

前章で得られた飛行状況に応じた予測モデルは、2.3.で述べたクラスタリングによりグループ化したデータセットに由来する。しかし実際の運航では、グループ化されたデータに対してではなく、各軌道に対する予測性能が重要となる。そこで本章では、前章で得た飛行状況に応じた予測モデルの実軌道データへの適応性を評価する。また、従来のモデルに相当する飛行状況ごとの変動を考慮しない期待値モデルとの比較評価も行い、飛行時間の不確かさの予測に飛行状況を考慮することの利点をより明確に示す。

本章でのモデルの予測性能評価には、モデル化に使用していないテスト用の軌道データ（データ数：5214）の 100km 飛行時の飛行時間誤差を用いる。

前章で得た飛行状況に応じたモデルに 10km 毎に通過点の数値気象予報値（真航路方向の風速、横風の絶対値、気温）と目標対地速度を入力し、その時のモデルの出力を逐次積分することで 100km 飛行した際の飛行時間誤差の標準偏差を予測する。一方、比較用の従来の研究に相当する期待値モデルの予測値として、前章までのモデル化に使用した同じ軌道データから求めた 100km 飛行時の飛行時間誤差の標準偏差を用いる。この値は 6.35[sec/100km]となった。これにより比較する 2 つの予測は、どちらもモデル化用のデータに由来しており本章で扱うテスト用のデータに対しては未知である。

5.1. 評価指標

飛行時間の不確かさの予測モデルは飛行時間誤差の標準偏差 $\sigma_{\Delta t}$ を予測値として出力する一方で、各実軌道データにおいて観測できるのは飛行時間誤差 Δt である。すなわち、単に予測値と観測値の差による予測性能の評価ができず、新たに予測性能の評価指標(Index)を導入する必要がある。ここで飛行時間誤差 Δt が平均値 0 の正規分布に従うとすると、飛行時間誤差の標準偏差 $\sigma_{\Delta t}$ を予測することは、飛行時間誤差が生起する元の分布を予測することに当たる。この予測が適切にできている場合、観測値 Δt と予測値 $\sigma_{\Delta t}$ の関係は式 (17) のように表せる。このとき、予測値 $\sigma_{\Delta t}$ で観測値 Δt を割った値の分布は標準正規分布になり、その標準偏差は 1 となる (式 (18))。この関係を利用して、100km 飛行時の飛行時間誤差の観測値 Δt をモデルの予測値 $\sigma_{\Delta t}$ で割った値の標準偏差を評価指標に用いる (式 (19))。言い換えれば、この評価指標は飛行時間誤差を予測値により正規化した値の標準偏差であり、適切な予測ができていない場合、正規化も適切に行われ、その標準偏差は 1 となる。また、Index がよりも小さい場合は、分母である予測値が適切な値より大きい、すなわち過大な予測に陥っていることを表す。逆に Index が 1 よりも大きい場合は、モデルが飛行時間の不確かさを過小に見積もっていることを表す。飛行時間の不確かさを過大に見積もってしまうと、必要以上に安全間隔をとってしまうなど運用上の効率を低下させる可能性があり、また過小な見積もりは、安全性を損なう危険性がある。この評価指標 Index の関係を式 (17) と表 2 に整理する。ただし、std.はつづくかっこ内の標準偏差を算出する演算子を表す。

$$Pr(\Delta t) = Norm[0, \sigma_{\Delta t}^2] \quad (17)$$

$$Pr\left(\frac{\Delta t}{\sigma_{\Delta t}}\right) = Norm[0, 1] \quad (18)$$

$$Index = std.\left[\frac{\Delta t}{\sigma_{\Delta t}}\right] \quad (17)$$

表 1：実軌道データへの適用性の評価指標

	評価	運用上の影響（例：時間間隔の設定）
Index=1	適切な予測	安全性を適切に確保した効率的な時間間隔を設定可能
Index<1	過大な予測	過剰な安全間隔による低効率化を招く可能性がある
Index>1	過小な予測	十分な安全性を確保できない危険性がある

5.2. 全軌道に対する平均的な予測性能

全テスト用データを対象にした、つまり飛行状況の区別なく平均的な予測性の評価では、従来の期待値モデルは 1.025、NN モデルは 1.017 となり、両モデルともに適切な予測ができていた。このときの各モデルの予測値で正規化した飛行時間誤差のヒストグラムを図 10 に示す。このヒストグラムからも、飛行状況を区別しない全テストデータを対象とした平均的な予測性能は比較する 2 つのモデルで差がないことがわかる。




図 12：予測値で正規化した飛行時間誤差のヒストグラム
（全テスト軌道を用いた評価）

5.3. 飛行状況に応じた予測モデルの有益性

飛行状況に応じた予測が可能な NN モデルの有益性をより明確に示すために、テスト用データを NN モデルの予測値が大きい順に 5 層に分割し、各層について前節と同様の方法で評価を行う。各層における従来の期待値モデルの評価指標を青で、NN モデルの評価指標を赤で図 13 に示す。期待値モデルでは、評価指標は 1 より小さい値から層につれて大きくなり最後の層においては 1 を大きく超えている。一方、NN モデルでは評価指標が 1 付近に比較的安定していることが分かる。この評価指標は、前述したように 1 であるとき適切な予測ができていることを示すが、1 より小さい場合は過大な、1 より大きい場合は過小な予測に陥っていることを示す。飛行時間の不確かさを過大に見積もってしまうと、必要以上に安全間隔をとってしまうなど運用上の効率を低下させる可能性がある。また過小な見積もりは、安全性を損なう危険性がある。




図 13：NN モデルの予測値で分割した層ごとの評価指標

また、NN 予測モデルの予測値の上位層 (0~20%)、すなわち生じうる飛行時間の誤差が大きいと予測されたデータ群における正規化された飛行時間誤差のヒストグラムを図 14 に示す。このとき期待値モデルに対応する分布は幅広な形状になり、飛行時間の不確かさを過小に見積もっていることがわかる。同様に NN モデルの予測値の下位層 (80~100%) についても評価した結果を図 15 に示す。この場合は、期待値モデルに対応する分布は狭くなり、過大な予測に陥っていることがわかる。

以上により、従来の期待値モデルと比較して、飛行状況に応じた予測が可能な NN モデルは飛行時間の不確かさを過大にあるいは過小に見積もることなく適切な予測ができることを示した。これは飛行状況を考慮した飛行時間の不確かさ予測を運航管理に導入することが、航空機の時間ベース運用の安全性と効率性の向上に貢献することを示唆するものである。




図 14：NN モデルの予測値の上位層での評価結果




図 15：NN モデルの予測値の下位層での評価結果

6. まとめ

本研究では、将来的に計画されている航空機の飛行時間の管理に飛行時間の不確かさを導入することでより高度な運航管理が期待できることに着目し、飛行時間の不確かさ予測の高精度化を試みた。その結果、飛行や気象の状況ごとの変動を反映したモデルによる飛行時間の不確かさのより高精度な予測の実現可能性を示した。

データ処理として、各航空機の目標飛行時間を精度よく推定するために、明らかな飛行意図をもって飛行している区間（指示大気速度を一定に保ち、継続的に直線巡航飛行している区間）を解析対象として実運航データから抽出した。また、飛行時間の不確かさを飛行状況ごとに解析すべく、抽出したデータから混合正規分布モデルを用いたソフトクラスタリングによって、飛行や気象の状況を表すパラメータと飛行時間誤差の標準偏差を対応付けたデータを作成した。

モデル化に向けて、力学モデルに基づいた飛行時間の誤差伝搬モデルを導出し、飛行時間誤差の標準偏差が対地速度の二乗に比例することを示した。また、この誤差伝搬モデルの予測性能を評価するなかで、飛行状況に応じて誤差要因の変動をモデルに反映することが予測の高精度化に有効であることを確認した。そこで、ニューラルネットワークモデルの学習機能を用いて、飛行意図や気象予報値（対地速度、真航路方向の風速、横風の風速、気温）と飛行時間誤差の標準偏差の関係を近似関数化し、飛行状況に応じた予測モデルの構築を試みた。得られた飛行状況に応じたモデルは、誤差伝搬モデルの実際的な予測性能より優れた性能を示した。さらに、この飛行状況に応じた予測モデルと従来の研究に相当する期待値モデルの実軌道データにおける予測性能を比較評価し、飛行や気象の状況ごとに変動する要因を予測に考慮することがより安全で効率のよい運航を可能にすることを示した。

本研究の最終目標は、航空交通管理に飛行時間の不確かさを新たな管理パラメータとして導入することで、より高度な運航管理を実現させることである。これに向けて本論文では、飛行時間の不確かさの予測に飛行状況による変動の影響を反映することで、高精度な予測が可能になるという実現可能性を示した。実運用化に向けては、予測モデルの信頼性が重要となるため、飛行時間の不確かさが生じるメカニズムを明確に示したモデルが必要となる。

7. 謝辞

本研究を遂行するにあたり、熱心なご指導を賜りました指導教官である武市昇准教授に深く感謝致します。また、日々の議論を通じて多くの刺激と示唆をいただいた航空宇宙システム運用工学研究室の皆様にも心から感謝致します。特に同期の下村顕秀くん、山内貴弘くんとは、研究室の一期生ということもあり多くの苦楽を共にしました。忙しくも楽しい、苦しくも笑える日々をありがとうございました。このほかにも多くの人に支えられ、勉学にかぎらず実りの多い2年間を過ごしました。最後に、これまで温かい目で見守ってくれた家族に深く感謝を申し上げます。

8. 参考文献

- [1] BOEING: CURRENT MARKET OUTLOOK 2013-2032, 2013.
- [2] 将来の航空交通システムに関する研究会：将来の航空交通システムに関する長期ビジョン, 国土交通省, 2010 年.
- [3] 矢田士郎: 四次元航法とそれに対応する管制に関する一考察, 第5回電子航法研究所研究発表会, 2005 年 6 月.
- [4] PAIELLI, R.A., AND ERZBERGER, H.: CONFLICT PROBABILITY FOR FREE FLIGHT, JOURNAL OF GUIDANCE, CONTROL, AND DYNAMICS, VOL. 20, NO. 3, 1997, PP. 588-596.
- [5] IRVINE, R. : A GEOMETRICAL APPROACH TO CONFLICT PROBABILITY ESTIMATION, AIR TRAFFIC CONTROL QUARTERLY, VOL. 10, NO. 2, 2002, PP. 85-113.
- [6] PAIELLI, R.A.: EMPIRICAL TEST OF CONFLICT PROBABILITY ESTIMATION, USA/EUROPE AIR TRAFFIC MANAGEMENT RESEARCH AND DEVELOPMENT SEMINAR, ORLANDO. 1998.
- [7] ROBERT, E. AND DE SMEDT, D.: COMPARISON OF OPERATIONAL WIND FORECASTS WITH RECORDED FLIGHT DATA, 10TH USA/EUROPE AIR TRAFFIC MANAGEMENT RESEARCH AND DEVELOPMENT SEMINAR. CHICAGO, JUNE 10-13, 2013.
- [8] TAKEICHI, N., TACHIBANA, M., ABUMI, Y., AND BAYASGALAN, E.: WAYPOINT OPTIMIZATION FOR ACCURATE PSEUDO-RTA IN DESCENT TRAJECTORY, IEEE/AIAA 34TH DIGITAL AVIONICS SYSTEMS CONFERENCE, PRAGUE, SEPTEMBER 13-17, 2015.
- [9] SENOGUCHI, A. AND KOGA, T.: ANALYSIS OF DOWNLINK AIRCRAFT PARAMETERS MONITORED BY SSR MODE S IN ENRI, 28TH DIGITAL AVIONICS SYSTEMS CONFERENCE. , ORLANDO, FLORIDA, OCTOBER 25-29, 2009.
- [10] 気象庁データ オリジナルデータ 数値予報 GPV - 生存圏データベース:
[HTTP://DATABASE.RISH.KYOTO-U.AC.JP/ARCH/JMADATA/DATA/GPV/ORIGINAL/](http://DATABASE.RISH.KYOTO-U.AC.JP/ARCH/JMADATA/DATA/GPV/ORIGINAL/)
- [11] REDNER, R. A. AND WALKER, H. F. ; MIXTURE DENSITIES, MAXIMUM LIKELIHOOD AND THE EM ALGORITHM, SIAM REVIEW, VOL.26, NO.2, 1984
- [12] 宮本定明: クラスター分析入門, 第 1 版, 東京, 森北出版株式会社, 1993 年, p53-56
- [13] K, FUNAHASHI; ON THE APPROXIMATE REALIZATION OF CONTINUOUS MAPPING BY NEURAL NETWORK, NEURAL NETWORK, VOL.2, 1989
- [14] TREVOR, H. , ROBERT, T. AND JEROME, F. : 統計的学習の基礎, 初版, 東京, 共立出版株式会社, 2016 年, p277-278, p443-461